

# TISSUE CHARACTERISATION IN SPECTRAL CT DATA

**Veronika Poláková**

Bachelor Degree Programme (3), FEEC BUT

E-mail: xpolak35@vutbr.cz

Supervised by: Roman Jakubíček

E-mail: jakubicek@feec.vutbr.cz

**Abstract:** This article deals with tissue characterisation in virtual monoenergetic images (VMI). It presents that with growing energy of VMI the median of CT number increases or decreases with different steepness depending on a type of tissue. As a consequence, some VMI enable better soft tissue distinction and therefore their better classification. To determine which VMI are best suited, Cohen d was used. After that, Random Forest classification algorithm was applied to these images. If median of pixels is considered in addition to pixels themselves, the tissues can be classified correctly.

**Keywords:** spectral CT, image segmentation, descriptive statistics, supervised machine learning

## 1 ÚVOD

Výpočetní tomografie (CT) je jedna ze základních zobrazovacích modalit současnosti. Výhodou CT je rychlá akvizice dat, naopak za nevýhody se považuje zátěž pacienta radiačním zářením a horší kontrastní rozlišení měkkých tkání. Obě negativa se snaží výzkum řešit, přičemž tato práce se zaměřuje pouze na druhý problém.

Zatímco klasické CT používá ke tvorbě obrazu pouze jedno polyenergetické spektrum rentgenového (RTG) záření, spektrální CT jich používá více a lze ho tedy chápat jako souhrnné označení pro Dual-Energy CT (DECT) a Multi-Energy CT (MECT) systémy. Zatímco MECT není komerčně dostupné a je ve fázi vývoje, DECT existuje na trhu v různých provedeních a nabízí vytvořit množství virtuálních (uměle dopočítaných) obrazů, které mohou napomáhat při diagnostice. Tato práce se zaměřovala na tzv. virtuální monoenergetické obrazy (VMI), které simulují, jak by obraz vypadal při průchodu RTG záření pouze o jedné energii [1]. Charakterizace tkání pomocí CT čísel na těchto obrazech nám může zodpovědět otázku, zda některé VMI poskytují lepší kontrastní rozlišení daných tkání než obrazy z klasického CT. Pokud by tomu tak bylo, mohou nám tyto obrazy dopomoci ke snadnější automatické klasifikaci tkání i jejich segmentaci, která je nyní problematická z důvodu podobných CT čísel jednotlivých tkání.

## 2 DOSTUPNÁ DATA A ZÍSKÁNÍ DAT PRO CHARAKTERIZACI TKÁNÍ


K dispozici byla data 14 pacientů nasnímaná zařízením *IQon Spectral CT* od firmy Philips. Jedná se o „dual-layer“ DECT, který nabízí rekonstruktor pro tvorbu VMI, ale i dalších parametrických obrazů. Byly vytvořeny VMI s několika reprezentativními energiemi, konkrétně 40, 50, 55, 60, 65, 70, 80, 90, 100, 120, 140 a 160 keV. Největší změna v podobě obrazů byla subjektivně zaznamenána v rozsahu 50–70 keV, proto se zde postupovalo s jemnějším krokem, naopak obrazy nad 100 keV vypadaly podobně, a proto zde bylo postupováno s větším krokem. Jako reference byly pomocí rekonstruktoru vytvořeny i obrazy analogické těm z klasického CT dále označovány jako kCT.

Z vytvořených parametrických obrazů bylo potřeba vybrat jednotlivé tkáně segmentačními technikami. Pro lepší kontrolovatelnost segmentace probíhala na 2D řezech a to zejména metodami narůstání oblastí a aktivních kontur. Výsledek těchto metod však vyžadoval značné ruční úpravy. Pro co největší reprezentativnost tkáně byla její data nasbírána aspoň z jednoho axiálního, sagitálního a frontálního řezu. Nicméně tímto přístupem byl získán u různých velikých tkání různý počet dat, což není žádoucí z důvodu požadavku nezávislosti klasifikace na velikosti tkání (poměr velikostí tkání se může

s číslem řezu měnit). Tato práce si tedy kladla za cíl u všech tkání nasbírat přesně 25 000 pixelů<sup>1</sup>. Segmentaci tkáně bylo potřeba pečlivě provádět pouze na jednom parametrickém obrazu, jelikož výsledek segmentace byl uložen ve formě binární masky. Vynásobením této masky s dalšími parametrickými obrazy získáme potřebné údaje o tkáni na kCT obrazu i napříč spektrem energií VMI. Finálním krokem bylo uložení všech dat do databáze, z které lze následovně vybírat požadovaná data. Tímto postupem byla získána data u 9 pacientů.

### 3 CHARAKTERIZACE TKÁNÍ

Bylo zjištěno, že s měnící se energií VMI se mění i medián CT čísla tkáně. U některých tkání medián CT čísla s rostoucí energií roste, naopak u jiných tkání klesá. Tento růst a pokles je u různých tkání různě strmý, což může pomoci při jejich klasifikaci. Práce se zaměřovala na rozlišení vybraných dvojic tkání, které anatomicky leží blízko u sebe (konkrétně játra/ledvina, tepenná krev/žilná krev, mícha/koňský ohon a meziobratlová ploténka/velký bederní sval). Příklad charakterizace jedné takové dvojice tkání ukazuje Graf 1.



**Graf 1:** Graf zobrazuje charakterizaci tkání na jednotlivých parametrických obrazech, přičemž střed krabice je medián, okraje krabice tvoří horní a dolní kvartil, fousky jsou délky trojnásobku mezikvartilového rozpětí a pluska značí velmi odlehlé hodnoty. Zcela vlevo je vidět charakterizace tkání na referenčním kCT obrazu, následují charakterizace na jednotlivých VMI o dané energii. Medián CT čísla velkého bederního svalu i meziobratlové ploténky na těchto obrazech s rostoucí energií klesá, resp. neroste, jak je vidět nejen z boxplotů, ale i mediánů barevně vypsanych ve spodní části grafu. Dále je patrné, že u svalu je strmost poklesu mediánu CT čísla mnohem menší než u meziobratlové ploténky. Tento charakter vybraných tkání není však pravidlem u všech pacientů.

Rozlišení tkání na jednotlivých obrazech nezáleží pouze na rozdílnosti mediánu tkání, ale i na míře variability CT čísel. Proto jako kritérium míry rozdílnosti tkání bylo v práci zvoleno *Cohenovo d* dané rov. 1, kde  $x_1$  (resp.  $x_2$ ) je průměrná hodnota pixelů první (resp. druhé) tkáně<sup>2</sup> a  $\sigma$  je sdružená směrodatná odchylka<sup>3</sup>.

$$d = \frac{|\bar{x}_1 - \bar{x}_2|}{\sigma} \quad (1)$$

<sup>1</sup>Tento počet byl zvolen jako zlatý střed, jelikož příliš vysoký počet učiní segmentaci malých tkání zbytečně zdlouhavou či dokonce nemožnou (tkáň je natolik malá, že tolik hodnot u ní nelze nasbírat), naopak příliš nízký počet podává malou informaci o větších tkáních.

<sup>2</sup>Zkoumané tkáně graficky nabývají normálního rozložení, tedy jejich medián odpovídá průměru.

<sup>3</sup>Sdružená směrodatná odchylka se vypočítá dle vztahu  $\sigma = \sqrt{\frac{(n_1-1)\cdot\sigma_1^2 + (n_2-1)\cdot\sigma_2^2}{n_1+n_2-2}}$ , kde  $\sigma_1$  (resp.  $\sigma_2$ ) je výběrová směrodatná odchylka první (resp. druhé) tkáně a  $n_1$  (resp.  $n_2$ ) je velikost vzorku první (resp. druhé) skupiny.

Tímto postupem lze určit, zda a který VMI poskytuje lepší rozlišení zvolených tkání než kCT obraz. Platí, že čím větší d, tím lépe tkáň rozeznáme. Za přijatelnou hodnotu se považuje 0,8 a vyšší [2], které z doposud zkoumaných tkání nabývaly dvojice játra/ledvina a meziobratlová ploténka/velký bederní sval. Naopak dvojice tepenná krev/žilní krev a mícha/koňský ohon na žádném z parametrických obrazů hodnoty 0,8 nedosáhly, a proto lze prohlásit, že ani na VMI se nám nepodaří je účinně rozlišit. Tabulka Cohenova d pro různé dvojice tkání u daného pacienta vypadá následovně:

	kCT	40 keV	50 keV	55 keV	60 keV	65 keV	70 keV	80 keV	90 keV	100 keV	120 keV	140 keV	160 keV
VBS/MP	1,81	1,51	1,74	1,86	1,93	1,97	1,99	2,00	2,00	1,98	1,96	1,94	1,93
J/L	1,99	1,35	1,79	2,03	2,21	2,36	2,47	2,62	2,71	2,76	2,82	2,84	2,85
TK/ŽK	0,10	0,22	0,19	0,19	0,18	0,17	0,17	0,15	0,14	0,14	0,13	0,12	0,12
M/KO	0,33	0,12	0,27	0,34	0,39	0,44	0,47	0,51	0,53	0,54	0,55	0,56	0,56

**Tabulka 1:** Cohenovo d pro různé dvojice tkání, přičemž zelená barva je vždy u parametrického obrazu, který nabízí nejlepší rozlišení dané dvojice. VBS/MP = velký bederní sval/meziobratlová ploténka, J/L = játra/ledvina, TK/ŽK = tepenná krev/žilní krev, M/KO = mícha/koňský ohon.

#### 4 KLASIFIKACE TKÁNÍ

Pro klasifikaci byl zvolen algoritmus náhodného lesa („Random Forest“), který vytváří efektivní klasifikátor na základě učení s učitelem. Počet stromů byl zvolen jako 20 na základě analýzy tzv. „out of bag“ chyby při různých počtech stromů. Trénovací data byla čerpána z vytvořené databáze dat, testovacími daty pak byla náhodně vybraná část obou tkání na náhodném snímku (avšak jiném, než na kterém byla sbírána trénovací data) u daného pacienta. Snahou bylo dosáhnout dobré klasifikace s využitím co nejméně parametrických obrazů z důvodu menší výpočetní a časové náročnosti.

Klasifikace tkání na základě jednotlivých pixelů (Obrázek 1a) dosahovala s využitím vhodných VMI (výběr podle Cohenova d) úspěšnosti o 1 až 10 % (výjimečně i více procent) lepší než na kCT obrazu.

Mnohem lepších výsledků klasifikace bylo dosaženo, pokud byly místo samotných pixelů využity statistické charakteristiky tkáně, konkrétně medián (Obrázek 1b). Trénovací data byla vytvořena mediánovou filtrací dat dané tkáně uložených v databázi. Testovací data byla získána vypočtením mediánu z hodnot získaných ze samotného pixelu, který chceme správně zařadit, a jeho kruhového okolí. Přitom platí, že počet dat, ze kterých se počítal medián u trénovacích i testovacích dat je stejný. Nutno podotknout, že tímto postupem nebylo dosaženo dobrých výsledků jen na VMI, ale i na kCT obraze. Pro správnou klasifikaci na tomto obraze však zpravidla musel být medián vypočten z většího okolí, což by ztěžovalo detekci menších útvarů.

Srovnání přesností klasifikace pomocí obou výše popsaných přístupů ukazuje Tabulka 2.


	kCT	VMI	kCT	VMI
přesnost	72,21 %	86,91 %	96,06 %	100,00 %

**Tabulka 2:** Přesnost klasifikace pro samotné pixely (levá část tabulky) a pro region pixelů (pravá část tabulky). Číslo vyjadřuje poměr správně zařazených pixelů ku všem použitým pixelům souhrnně pro všechny pacienty a uvažované dvojice tkání. Těmi byly tkáň s Cohenovým d větším než 0,8, tedy velký bederní sval/meziobratlová ploténka a játra/ledvina. Poloměr kruhového okolí pixelu byl vždy nastaven tak, aby klasifikace pomocí VMI byla stoprocentní.

Limitací přístupu založeného na výpočtu mediánu z regionu pixelů je skutečnost, že mezi tkáněmi vytváří mnohdy nerealistickou hranici (zejména v případech velmi konvexních hranic jako je např. u dvojice meziobratlová ploténka/velký bederní sval). Čím menší okolí pixelu při tvorbě mediánu bylo uvažováno, tím lépe šla pozorovat skutečná hranice, nicméně menší okolí mělo zase negativní vliv na úspěšnost klasifikace (nejmenší možné okolí je nulové, tedy vracíme se k situaci, kdy při klasifikaci uvažujeme samotné pixely). Proto byly přístupy klasifikace na základě samotných pixelů a regionu pixelů zkombinovány. Nejdříve byly klasifikovány samotné pixely s pomocí VMI. Pozorovaná hranice však byla nesouvislá, a proto bylo rozhodnuto proložit ji vyhlazujícím splajnem. Pro správné nalezení hranice, která má být vyhlazena, byly učiněny následující kroky:

- 1) Z výsledků klasifikace pomocí samotných pixelů byly vytvořeny binární masky obou tkání. Jedna z těchto masek byla vyhlazena pomocí morfologické operace otevření a následného uzavření. Druhá maska je doplňkem masky první v univerzu tvořeném oblastí zájmu.
- 2) Byly nalezeny hrany jako možné hranice mezi tkáněmi. Pokud pixel  $p(r-1, s)$  patří dle masek do první tkáně a pixel  $p(r+1, s)$  do druhé tkáně, pak pixel  $p(r, s)$  tvoří horizontální hranu. Podobně bylo postupováno i u vertikálních a diagonálních hran.
- 3) Byla nalezena nejdelší hrana, která byla proložena vyhlazujícím splajnem. Pokud RMSE bylo menší než určená limitní hodnota přípustné chyby, byla nalezena správná hranice. V opačném případě byl zřejmě místo hranice nalezen shluk pixelů, které byly kvůli nedokonalé klasifikaci na počátku určeny jako hranice. Tato možnost byla z kandidátů na možné hranice vyloučena a pokračovalo se znovu od začátku tohoto bodu, dokud nebyla nalezena vyhovující hranice.

Po nalezení hranice byla vymezena dvě úzká pásma kolem hranice (jedno nad a jedno pod hranicí), kde byly pixely zařazeny podle majoritní skupiny pixelů v tomto pásmu. Šířka tohoto pásma byla rovna poloměru kruhového okolí, ze kterého se následně bude počítat medián. Tímto krokem zajistíme zachování konvexnosti hranice. Pixely mimo hranici a pásma lze následně zařadit již výše popsaným způsobem pomocí mediánu tohoto pixelu a jeho okolí. Výsledek zobrazuje Obrázek 1c.



**Obrázek 1:** Klasifikace tkání pomocí algoritmu náhodného lesa na vybrané oblasti zájmu s pomocí jednotlivých pixelů (a), regionu pixelů (b) a kombinovaného přístupu vhodného pro určení konvexních hranic (c). Modrá barva odpovídá velkému bedernímu svaly, červená barva meziobratlové ploténce. Ke klasifikaci byl využit VMI 90 keV.

## 5 ZÁVĚR

Byl vytvořen postup pro charakterizaci tkání na několika parametrických obrazech. Na dostupných datech bylo prokázáno, že VMI zlepšují kontrastní rozlišení některých měkkých tkání, přičemž míru jejich odlišnosti na daném obraze lze posoudit pomocí Cohenova d. Díky faktu, že na vybraných VMI jsou dané tkáně lépe rozlišitelné než na kCT obraze, je možné je na těchto obrazech lépe klasifikovat. Účinnější klasifikace bylo dosaženo pokud místo samotných pixelů byly raději uvažovány statistické charakteristiky určitého regionu, přičemž u VMI stačí pro správnou klasifikaci zpravidla menší region než na kCT obraze. To umožňuje například detekovat ve tkáni menší oblasti, které se svými statistickými charakteristikami od tkáně liší (cévy probíhající tkání, cysty, nádory, apod.). Pokud jde o určení věrohodné hranice mezi tkáněmi, je potřeba kombinovat klasifikaci pomocí samotných pixelů i regionu pixelů. Jestliže dokážeme tuto hranici určit, můžeme tkáně účinně segmentovat.

## REFERENCE

- [1] FORGHANI, Reza, Bruno DE MAN a Rajiv GUPTA. Dual-Energy Computed Tomography: Physical Principles, Approaches to Scanning, Usage, and Implementation: Part 2. *Neuroimaging Clinics of North America* [online]. 2017, **27**(3), Dual Energy CT: Applications in Head and Neck and Neurologic Imaging, 385–400 [cit. 2018-03-10]. DOI: 10.1016/j.nic.2017.03.003. ISSN 1052-5149.
- [2] SULLIVAN, Gail M. a Richard FEINN. Using Effect Size—or Why the P Value Is Not Enough. *Journal of Graduate Medical Education* [online]. 2012, **4**(3), 279–282 [cit. 2018-03-10]. DOI:10.4300/JGME-D-12-00156.1. ISSN 1949-8349.